

AGRONOMSKI GLASNIK 1-2/2014.
ISSN 0002-1954

*Izvorni znanstveni članak
Original scientific paper*

MODEL INTERPRETACIJSKE BAZE ZEMLJIŠNIH RESURSA OSJEČKO-BARANJSKE ŽUPANIJE

INTERPRETIVE BASE MODEL OF LAND RESOURCES OF THE OSIJEK-BARANJA COUNTY

**Vesna Vukadinović, V. Vukadinović, Irena Jug, Ž. Kraljičak,
D. Jug, B. Đurđević**

SAŽETAK

U radu je predstavljen model interpretacijske baze zemljišnih resursa Osječko-baranjske županije koja, nakon 10 godina provođenja projekta „Kontrola plodnosti tla na obiteljskim poljoprivrednim gospodarstvima“, obuhvaća površinu oko 75 000 ha, sadrži ~ 25 000 slogova i više od 1 000 000 podataka, odnosno informacija. Model je podržan originalnim računalnim programom (ALR_{xp}) za utvrđivanje relativne pogodnosti poljoprivrednog zemljišta za usjeve, potrebe za kalcijacijom ili drugim vidom popravaka nepovoljnih fizikalno-kemijskih svojstava i izračun gnojidbene preporuke za konkretni usjev u sustavu konvencionalne, integrirane i ekološke proizvodnje. Automatska interpretacija rezultata temelji se na 50-ak ekspertnih pravila koja omogućavaju proračun potreba u gnojidbi i u narednom periodu za šest najzastupljenijih usjeva u Republici Hrvatskoj te i procjenu N-mineralizacije. Rezultati proračuna zajedno sa svim podacima spremaju se u izlaznu bazu (iBazu) namijenjenu geostatističkoj analizi poljoprivrednog prostora i vizualiziraju na tematskim kartama uz mogućnost online i offline pristupa svim podacima.

Ključne riječi: interpretacijska baza, gnojidbene preporuke, geostatistička analiza

ABSTRACT

This paper presents an interpretive base model of land resources of the Osijek-Baranja County. After 10 years of conducting the project “Control of soil quality on family farms” the base, covering an area of about 75 000

hectares, containing ~ 25 000 records and more than one million land data were created. The model is supported by an original computer program (ALRxp) which can determine the relative suitability of agricultural land for crops, the need for liming or other type of repairs like physical and chemical properties of soil and also calculate fertilizer recommendations for specific crops in conventional, integrated and organic agricultural production. Automatic interpretation of results is based on 50 expert rules which allow the calculation of fertilizer recommendations for upcoming period of six most represented crops in the Republic of Croatia and also the assessment of N-mineralization. The model results together with all other land data are stored in the so-called output base (iBase) which is ready for geostatistical analysis of the agricultural land and visualization on thematic maps with the possibility of online and offline access to all data.

Key words: interpretive base, fertilizer recommendations, geostatistical analysis

UVOD

Procjena pogodnosti tla/zemljišta uključuje izmjeru i interpretaciju ektomorfoloških, fizikalno-kemijskih i bioloških svojstava tala, vegetacije, klime, kao i niza sociološko-ekonomskih i tehničko-tehnoloških pokazatelja potrebnih za odabir najpovoljnijeg načina korištenja tla/zemljišta. Stoga *procjena (vrednovanje) zemljišta* predstavlja proces procjene potencijala zemljišta za različite načine korištenja (Dent i Young, 1981). Prema novom konceptu kvalitete tla (Karlen i sur., 1997) procjena zemljišta više nije samo procjena kvalitete bez bioloških svojstava, jer niz indikatora, kao što su mikorizne grupe, zajednice glista i slično, međusobno ima vrlo dinamičan odnos te pokazuje iznimnu osjetljivost na promjene u tlu. Rezultat procjene je izračun apsolutne ili relativne pogodnosti tala/zemljišta te njihovo svrstavanje u klase pogodnosti temeljem stupnja ograničenja prema rastu i razvoju različitih poljoprivrednih kultura.

Ubrzani razvoj informatičke tehnologije omogućio je sve više računalnih modela koji se danas uspješno koriste za vrednovanje zemljišta ovisno o njegovim svojstvima, kao što su plodnost i kvaliteta, ali i tržišna cijena. Jedan od aspekata njihove primjene je i procjena mogućeg prinosa usjeva, opskrbe tla hranjivim tvarima i potrebe gnojidbe, utjecaja na okoliš, opasnosti od erozije,

kao i procjena obradivosti. Računalnim modelom moguće je procijeniti i posljedice nastale različitim načinima gospodarenja tлом (Rossiter, 1996, 2003; Vukadinović i sur., 2008).

Interpretacijska baza zemljišnih resursa Osječko-baranjske županije (iBaza), nastala nakon 10 godina trajanja projekta „Kontrola plodnosti tla na poljoprivrednim gospodarstvima“, trenutno sadrži oko 25 000 slogova, s preko 1 000 000 podataka. Njih čine rezultati kemijskih analiza tla, podaci o uređenosti parcela, edafskim čimbenicima, usjevima (prethodnim i planiranim), primijenjenoj agrotehnici i zaštiti usjeva, teksturi i biogenosti tla. Svi su ovi podaci potrebni za izradu gnojidbenih preporuka, kao i rezultati geostatističke analize poljoprivrednog proizvodnog prostora Osječko-baranjske županije (Vukadinović i sur., 2012). S obzirom da su uzorci tla geopozicionirani pomoću GPS uređaja lako ih je integrirati sa satelitskim, topografskim ili nekim drugim kartama, ali i s Arkodom (Jurišić i Plaščak, 2009) koji, između ostalog sadrži prikaz parcela, njihovu oznaku, vrstu poljoprivredne proizvodnje.

iBaza Osječko-baranjske županije na temelju *Koncepta zemljište* (Vukadinović i Vukadinović, 2011), osim tla i njegovih fizikalno-kemijsko-bioloških svojstava, uključuje i druge indikatore pogodnosti zemljišta (klimatske, ekološke, orografske, hidrološke, agrotehničke, potencijal mineralizacije organske tvari, znanje korisnika) važne za njegovu različitu, prvenstveno poljoprivrednu namjenu. Stoga je uzorkovanje tla organizirano uz korištenje GPS uređaja radi točnog geopozicioniranja *kontrolne parcele* (Vukadinović i Bertić, 2013) unutar proizvodne površine. Time je omogućena geostatistička obrada i vizualizacija (Krishna, 2013) na tematskim kartama proizvodnog potencijala poljoprivrednog prostora ili njegovog zdravlja. Naime, zdravlje tla nije puki sinonim za njegovu plodnost, već okosnica *Koncepta zemljište*, a definira se kao “*Kapacitet specifičnih funkcija tla unutar prirodnog ili ograničeno uređenog ekosustava koji podržava biljnu i animalnu produkciju, održava ili povećava kvalitetu vode i zraka i potpomaže zdravlje i stanovanje ljudi.*” (Harris i sur., 1996).

Plodnost tla čini fizikalna sredina specifičnih kemijskih i bioloških svojstava, karakterističnih za antropogenizirana tla, te definira sposobnost tla osigurati biljkama potrebnu hranu u adekvatnim količinama i omjerima. Kako je to vrlo složeno i ujedno najvažnije svojstvo tla nije ga moguće apsolutno kvantificirati te se umjesto plodnosti sve češće definira i primjenjuje termin

pogodnost tla s obzirom na agronomske, ekološke, ekonomske, sociološke i tehnološke aspekte konkretne biljne proizvodnje (Vukadinović i Vukadinović, 2011). Ključni atribut pogodnosti tla je potreba usjeva i njegovi minimalni zahtjevi za edafskim činiteljima, kao i potrebna razina tehnologije koja ne ugrožava mogućnost korištenja tla, naročito kada su moguća dodatna ulaganja. Budući da se radi o računalnom modelu kakvoća tla i zahtjevi za njegovim korištenjem moraju biti mjerljivi što nije uvijek lako niti moguće posve točno utvrditi.

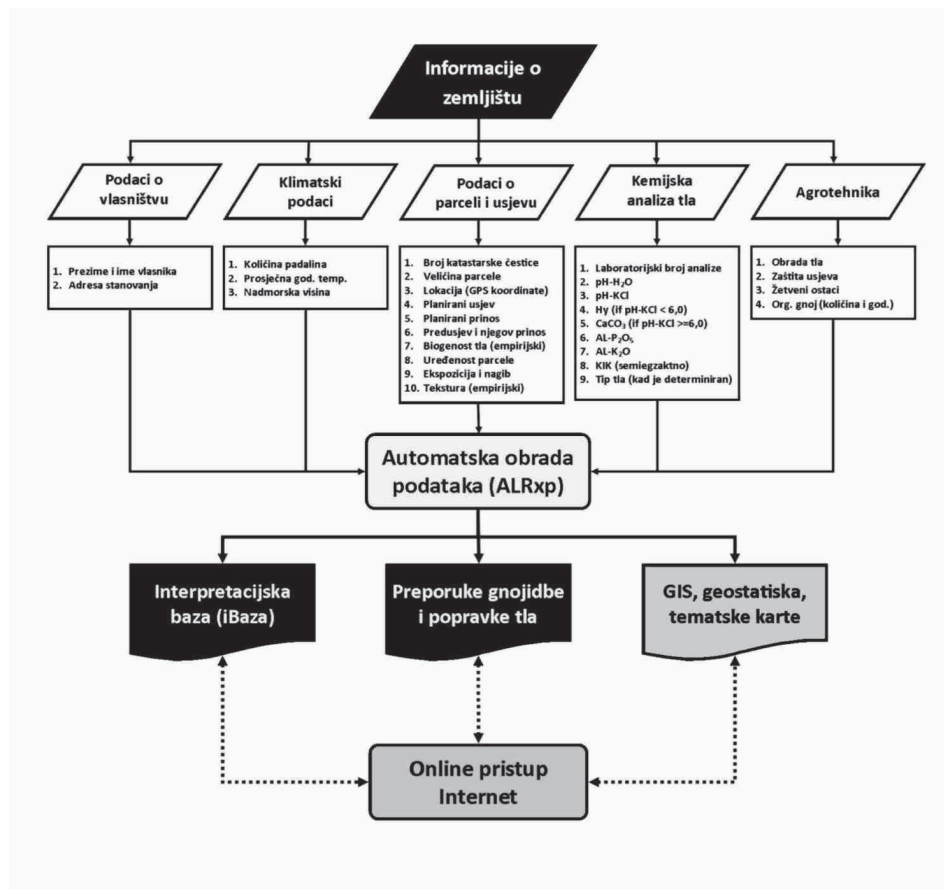
Kako je većina GIS aplikacija razvijena za vizualizaciju prostornih podataka, a samo mali dio za analizu, predikciju i modeliranje (Bregt i Bulens, 1998; Hartkamp i sur., 1999), kreiran je model iBaze koji povezuje prostornu distribuciju podataka o tlu oplemenjenu mogućnošću predikcije i analize cjelokupnog poljoprivrednog područja.

Također, prikazani model iBaze usklađen je s načelima dobre poljoprivredne prakse (Piorr, 2003; Katalinić i sur., 2009) te su preporučene doze hraniva usklađene s potrebama usjeva uz minimalno ekološko opterećenje okoliša. Model je trenutno reduciran na agronomske i biološko-ekološke indikatore pogodnosti zemljišta te obuhvaća dijelom i tehničko-tehnološke indikatore primarne produkcije organske tvari.

METODE RADA

Model interpretacijske baze zemljišnih resursa Osječko-baranjske županije (iBaza), shematski prikazan na Slici 1, obuhvaća pet grupa ulaznih podataka (uBaza). Obje baze (uBaza i iBaza) su relacijskog tipa u standardnom dbf formatu, ali moguće je koristiti i MS Excel čime se postupak unosa, editiranja i ažuriranja obje baze pojednostavljuje.

Rezultati kemijskih analiza tla upotpunjeni su i drugim parametrima produktivnosti zemljišta, a rezultat njihove računalne obrade je gnojidbena preporuka i iBaza neophodna za interpretaciju rezultata svakog pojedinačnog uzorka tla, kao i cijele parcele. Analizom iBaze GIS alatima (Hearnshaw i Unwin, 1994; Jurišić i Plaščak, 2009) dobivaju se rezultati koji se mogu vizualizirati prikazivanjem na tematskim agrokemijskim, proizvodnim, pedološkim i drugim kartama.



Slika 1: Shema Interpretacijske baze (iBaze) zemljišnih resursa istočne Hrvatske

Figure 1: Land resources interpretive base (iBase) scheme for eastern part of Croatia

Od GIS alata korišteni su ArcMap v10.2 (komercijalni), QGIS v1.8.0 i Google Earth v6.0 (GNU javna licenca), a kao podloge za geopozicioniranje rezultata analize korištene su satelitske i topografske karte, DMR (Digitalni model reljefa) te karte s javnog poslužitelja Državne geodetske uprave

(<http://geoportal.dgu.hr/wms>). Također, iBaza Osječko-baranjske županije integrirana je s Arkodom na razini parcele. Heterogenost proizvodne parcele, kao i cijelog područja izvedena je interpolacijskom tehnikom kriginga (Malvić, 2005).

Proračun relativne pogodnosti tla za uzgoj usjeva temelji se na Liebscherovoj modifikaciji Liebigovog „Zakona minimuma“ koji smatra da je djelovanje faktora u minimumu jače izraženo ako su ostali faktori prinosa bliži optimumu:

$$RP \% = \frac{\sum_{i=1}^n I - I_{\min}}{n - 1} \times \frac{I_{\min}}{100}$$

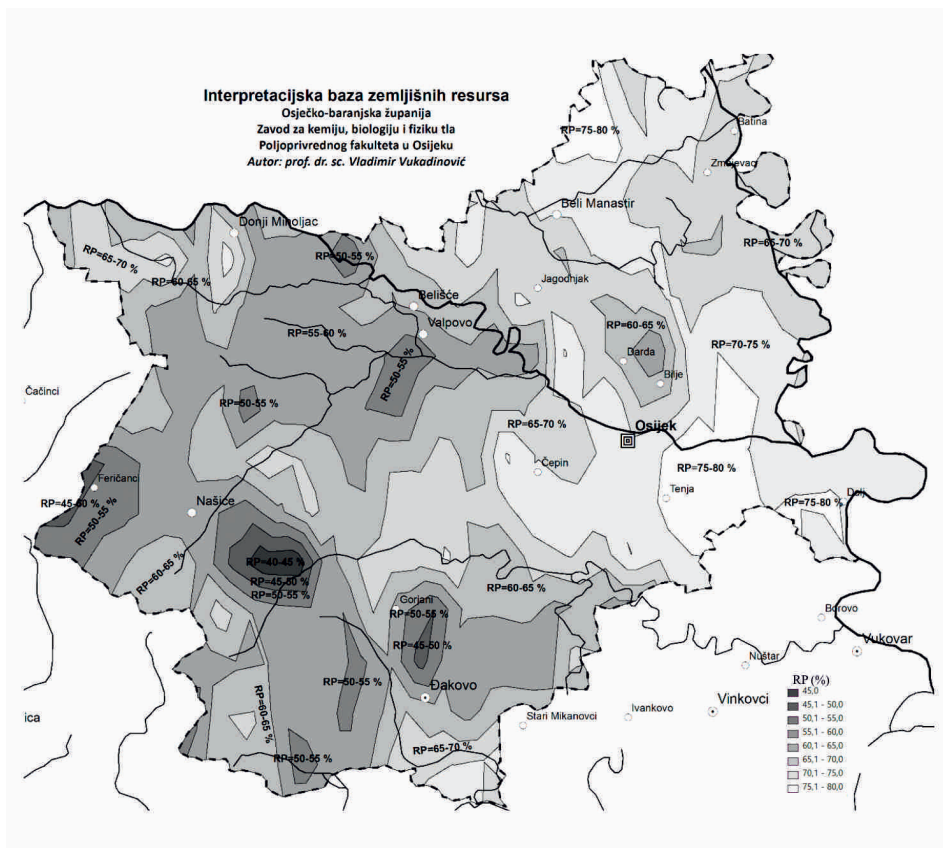
RP % = relativna pogodnost tla u %, I = indikator plodnosti, I_{\min} = indikator plodnosti u minimumu

Indikatori pogodnosti zemljišta uključuju raspoloživost hranjivih tvari (potencijal N-mineralizacije za vegetaciju pojedinog usjeva i raspoloživost P_2O_5 i K_2O), sadržaj humusa, karbonata i pH-vrijednost tla uz podatke o biogenosti, uređenosti zemljišta, intenzitetu primjene agrotehničkih mjera, geopoziciji (nagib, ekspozicija, nadmorska visina) i klimatskim značajkama područja. Proračun se obavlja ranije objašnjenim funkcijskim modelom. Međusobna interakcija pojedinih indikatora relativne pogodnosti, sukladno prirodnim zakonitostima, nelinearnog je tipa, a model se neprestano usavršava uvođenjem novih indikatora i prilagodbom oblika povezanosti.

Relativna pogodnost tla za usjeve (slika 2) koristi se za procjenu moguće visine prinosa najzastupljenijih usjeva (Tablica 2, Slika 3) uzgajanih na području istočne Hrvatske, tijekom sljedećeg proizvodnog razdoblja, odnosno do nove analize tla za konkretnu parcelu. Time je omogućena realna procjena potrebe u gnojidbi do narednog ciklusa analize tla, za oko 5 godina. Prvi korak je izračunavanje očekivane visine prinosa (OVP) na konkretnoj proizvodnoj površini. Formula za izračunavanje očekivane visine prinosa kukuruza je sljedeća:

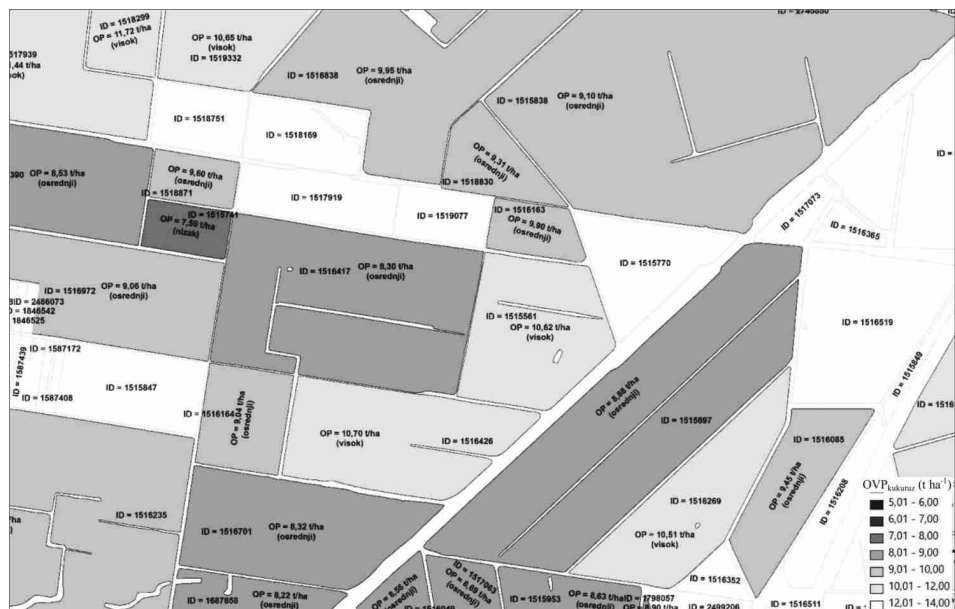
$$OVP_{\text{kukuruz}} (t \text{ ha}^{-1}) = \frac{RP \%}{100} \times \text{najviši mogući prinos} (t \text{ ha}^{-1})$$

Sukladno gornjoj formuli, ako je relativna pogodnost tla 80 %, a najviši mogući prinos suhog zrna kukuruza u istočnoj Hrvatskoj 15 t ha^{-1} , tada je očekivana visina prinosa 12 t ha^{-1} .



Slika 2: Relativna pogodnost zemljišnih resursa Osječko-baranjske županije (ArcMap 10.2) izračunata kriginom

Figure 2: The relative land resources suitability of the Osijek-Baranja county calculated by kriging (ArcMap 10.2)



*Slika 3: Očekivane visine prinosa kukuruza ($t\ ha^{-1}$) interpolirane krigingom
na podlozi Arkoda (ArcMap 10.2, M 1 : 10 000)*

*Figure 3: Kriging interpolation of expected corn yield ($t\ ha^{-1}$)
on ARKOD map (ArcMap 10.2, M 1 : 10 000)*

Tijekom višegodišnjih istraživanja na području istočne Hrvatske, koja su uključivala i kalibracijske gnojidbene pokuse najzastupljenijih usjeva u plodoredu, skupljen je velik broj podataka. Svi ti podaci, uključujući i rezultate složene multivarijacijske analize o uzajamnoj ovisnosti raspoloživosti hraniva, gnojiva i prinosa, ugrađeni su u aktualni ALR_{xp} kalkulator po principu "dinamičke potrebe hraniva" (Vukadinović i Vukadinović, 2011). Princip je da se iz odnosa očekivane visine prinosa prema najvišem mogućem ili maksimalnom prinosu (kukuruz = $15\ t\ ha^{-1}$) i najnižem prinosu koji se može postići bez gnojidbe (kukuruz $\sim 5\ t\ ha^{-1}$) složenim pravilom trojnim izračuna indeks potrebe hraniva (IPH). Izračunati IPH se pomoću polinomijalne funkcije, čiji je oblik u rasponu potrebe gnojidbe (uključuje i ekonomski maksimum

primjene pojedinih glavnih hraniva, na primjeru kukuruza to je 200 kg N ha⁻¹, 150 kg P₂O₅ ha⁻¹ i 225 kg K₂O ha⁻¹) sigmoidan, iskoristi za dinamičko prilagođavanje potrebe za hranivima.

$$IPH = \frac{OVP \times 100 \times (OVP - NVP)}{MVP \times (MVP - NVP)}$$

OVP = očekivana visina prinosa (t ha⁻¹); MVP = maksimalna visina prinosa (t ha⁻¹) i NVP = najniža visina prinosa bez gnojidbe (t ha⁻¹)

Dinamičku potrebu hraniva karakterizira veća učinkovitost korištenja hraniva kod visoke razine agrotehnike i ona uključuje (Vukadinović i Bertić, 2013) sljedeće:

- a) priming efekt (poticajni efekt, odnosno primjena niže doze aktivne tvari ima veću agronomsku efikasnost),
- b) humat efekt (blokada humusom Al³⁺ i drugih kationa čija koncentracija može biti vrlo visoka pri niskoj pH-vrijednosti tla, a prevode biljkama raspoloživi fosfor u kemijski oblik koji one ne mogu usvojiti),
- c) genetska svojstva biljne vrste s obzirom na efikasnost usvajanja i korištenja hraniva iz tla i
- d) visoku fiziološku adaptabilnost modernih kultivara.

REZULTATI RADA S RASPRAVOM

Za prikaz iBaze moguće je koristiti komercijalne i besplatne GIS alate. Naime, GIS programi imaju mogućnost prikaza, pretraživanja i editiranja relacijske baze. Sukladno tome izlistanje iz integrirane zemljišne baze prema postavljenim kriterijima jednostavno je za pojedini uzorak tla, ali i grupu uzoraka, kao i za svaku parcelu u vidu prosjeka pojedinog indikatora uz statističke pokazatelje varijacije (Tablica 1).

Tablica 1: Statistički pokazatelji nekih atributa iBaze (za 24 699 slogova)

Table 1: Statistical indicators of some iBase attributes (for 24 699 records)

Pokazatelj Indicator	Latituda Latitude	Longituda Longitude	Nadm. visina Altitude (m)	pH (KCl)	Humus (%) Organic matter	AL- P ₂ O ₅	AL- K ₂ O	CaO kg ha ⁻¹	RP %
						mg 100g ⁻¹			
Prosjek Average	-	-	91,9	5,67	2,13	19,36	23,60	1432	65,00
STD	0,226	0,330	18,3	1,21	0,74	10,89	8,46	1715	10,39
CV %	0,50	1,78	19,9	21,3	34,6	56,30	35,90	119,7	16,00
max	46,31853	19,23764	428,2	8,23	7,70	50,00	50,00	4375	87,34
min	44,76207	16,86483	74,7	3,16	0,32	0,40	3,60	0	2,50

Istraživanja su pokazala kako je poljoprivredna proizvodnja Osječko-baranjske županije organizirana ne samo u nizinskom nego i u brežuljkastom, odnosno brdovitom području (74,7 – 428,2 m.n.v.). Prosječne vrijednosti reakcije tla, izmjerene u 1 mol dm⁻³ KCl, ukazuju na umjereno kiselu tla (Soil Survey Division Staff, 1993), iako je raspon od ultra kisele (pH(KCl) = 3,16) do umjereno alkalne (pH(KCl) = 8,23) (Tablica 1). Osim toga, zemljišta su slabo humozna s visokim koeficijentom varijabilnosti (CV = 34,6 %). Prema rezultatima AL-metode, poljoprivredne površine Osječko-baranjske županije su, u prosjeku, dobro opskrbljene fosforom (AL-P₂O₅ = 19,36 mg 100g⁻¹ tla) i kalijem (AL-K₂O = 23,60 mg 100g⁻¹ tla) (Vukadinović i Vukadinović, 2011). Potrebe u količini materijala za kalcizaciju kiselih tala, ovisno o vrijednostima pH(KCl) i hidrolitičke kiselosti, kreću se do 4 375 kg ha⁻¹ (Tablica 1). Temeljem izračuna relativne pogodnosti vidljivo je kako su poljoprivredne površine, u prosjeku, u P2 klasi umjereno pogodnih zemljišta (FAO, 1976) za proizvodnju ratarskih kultura. Međutim, ne treba zanemariti ni činjenicu da su vrijednosti u vrlo širokom rasponu, od trajno nepodgovnih (N2 klasa) s relativnom pogodnosti 2,50 %, do visoko pogodnih parcela P1 klase (RP = 87,34 %). Rezultati procjene relativne pogodnosti poljoprivrednih

površina Osječko-baranjske županije za ratarsku proizvodnju geostatistički su obrađeni krigingom i vizualizirani na karti mjerila 1 : 350 000 (Slika 2).

Tablica 2: Očekivane visine prinosa ($t\ ha^{-1}$) ratarskih kultura na području Osječko-baranjske županije (17 792 uzoraka tla sa 6 416 parcela)

Table 2: Expected crops yield ($t\ ha^{-1}$) in the Osijek-Baranja County (17,792 soil samples from the 6,416 plots)

Klasa pogodnosti Land suitability classes	Broj uzoraka Number of samples	Očekivana visina prinosa ($t\ ha^{-1}$) Expected crops yield ($t\ ha^{-1}$)						
		Pšenica Wheat	Kukuruz Maize	Ječam Barley	Šeć. repa Sugar beat	Soja Soybean	Suncokret Sunflower	Ulj. repica Rapeseed
P1	818	7,79	12,29	7,38	73,76	4,92	4,67	4,59
P2	10820	6,66	10,52	6,31	63,10	4,21	4,00	3,93
P3	5859	5,03	7,95	4,77	47,68	3,18	3,02	2,97
N1	295	3,35	5,30	3,18	31,77	2,12	2,01	1,98
N2	0	-	-	-	-	-	-	-
Prosjeck Average	-	5,71	9,01	5,41	54,08	3,61	3,42	3,36

Uporabom GIS alata moguće je prikazati heterogenosti parcele prema bilo kojem pojedinačnom indikatoru pogodnosti zemljišta, posebice za potrebe diferencirane gnojidbe, kondicioniranja ili neke druge agrotehničke mjere, na način da se interpoliraju podaci iBaze za pojedini indikator i pridruže odgovarajućoj parceli. Za determinaciju heterogenosti pojedine parcele ili užeg područja potrebno je imati dovoljan broj analiziranih uzoraka tla kako bi predikcija krigingom bila uz prihvatljiv rizik pogreške.

Za optimalnu procjenu potrebe gnojidbe relativna pogodnost zemljišta za usjeve ima važnu ulogu jer omogućava predviđanja očekivane visine prinosa u narednom periodu nakon analize tla, a time i optimalnu razinu ulaganja. Naime, ključno pitanje gnojidbe je koliko hraniva treba unijeti u tlo kako bi se postigla očekivana visina prinosa, jer usjev iskoristi tek dio hraniva, ovisno o biljnoj vrsti, kultivaru, duljini vegetacije, te zemljišnim i klimatskim uvjetima. Uporabom ranije navedene formule izračunate su očekivane visine prinosa za sedam najčešćih ratarskih kultura na oranicama Osječko-baranjske županije (pšenica, kukuruz, ozimi ječam, šećerna repa, soja, suncokret, uljana repica) i prikazane u Tablici 2. Iz predloženih podataka je vidljivo kako nijedna od

istraživanih 6 416 parcela nije trajno nepogodna (N2 klasa) za ratarsku proizvodnju, a svega 1,65 % uzoraka je u klasi N1. Očekivane visine prinosa svih analiziranih kultura su izrazito niske upravo zbog toga što su to djelomično nepogodne poljoprivredne površine koje zahtijevaju puno ulaganja za povećanje plodnosti, a time i više prinose. Najviše uzoraka je u P2 klasi umjereno pogodnih tala (60 %). Međutim, činjenica da je < 5 % analiziranih uzoraka (818) u klasi visoko pogodnih tala (P1) za ratarsku proizvodnju može biti protumačena s pozitivnog, ali i negativnog aspekta s obzirom na tešku gospodarsku situaciju unazad nekoliko godina. Gledano s pozitivnog stajališta, ohrabruje informacija kako ipak ima i poljoprivrednih površina kojima se dobro gospodari zbog čega mogu dati i visoke prinose (Tablica 2), odnosno osigurati prihod. S druge strane, manje od 5 % visoko plodnih tala nameće zaključak kako je to mali postotak površina, odnosno poljoprivrednih proizvođača u Županiji koji se mogu nositi sa sve većim zahtjevima tržišta.

Osim vizualnog prikaza, svaki uzorak tla ili pojedina parcela, mogu se prikazati numerički te svaki korisnik iBaze može vlastitim dopunskim kalkulatorima proračuna i optimizacije gnojidbe (<http://nss.com.hr/gnojidba.htm>) prilagoditi gnojidbenu preporuku specifičnim potrebama.

Za online pregled integrirane baze korisnika poljoprivrednog zemljišta praktično je koristiti Google Earth. Razlog je što on ne mora biti instaliran na lokalnom računalu već se vizualizacija realizira uz pomoć programa Google API (*Application Programming Interface*) <http://pedologija.com.hr/karte.htm>), čije su mogućnosti s aspekta geoinformatike praktično neograničene.

ZAKLJUČCI

Model interpretacijske baze zemljišnih resursa Osječko-baranjske županije (iBaza) podržan je originalnim ekspertnim računalnim programom (ALR_{xp}) za izračun relativne pogodnosti zemljišta (RP), potrebe u gnojidbi, popravke tala, kao i terenskoj, laboratorijskoj i geostatističkoj analizi podataka. Trenutno iBaza sadrži preko 1 000 000 podataka, koji su prikupljeni tijekom 10 godina trajanja projekta Osječko-baranjske županije „Kontrola plodnosti tla na poljoprivrednim gospodarstvima“, a njih čine rezultati kemijskih analiza ~ 25 000 uzoraka tla, podaci o uređenosti parcela, edafskim čimbenicima, usjevima, primijenjenoj agrotehnici i zaštiti, teksturi i biogenosti tla. Kod prikupljanja na

terenu svi su uzorci geopozicionirani pomoću GPS uređaja te se mogu integrirati s različitim kartama (satelitskim, topografskim) i Arkodom. Statistička obrada dijela atributa iBaze je pokazala kako su, prema prosječnim vrijednostima, poljoprivredne površine Županije umjereno kisele reakcije, slabo humozne te dobro opskrbljene biljkama pristupačnim kalijem i fosforom. Procjena relativne pogodnosti svrstava istraživane parcele od N2 do P1 klase pogodnosti, prema FAO (1976). Korištenjem relativne pogodnosti može se izračunati i očekivana visina prinosa, koja je u pravilu niža što je relativna pogodnost lošija.

Zbog svoje potpune integracije s GIS-om, jednostavnosti i praktičnosti, opisani model iBaze zemljišnih resursa je vrlo pogodan za procjenu pogodnosti zemljišta, a uz neznatne prilagodbe može se koristiti i za druge agroekološke uvjete.

LITERATURA

1. Bregt, A.K., Bulens, J.D. (1998): Integrating GIS and process models for land resource planning, in: Heineke, H.J., Eckelmann, W., Thomasson, A.J., Jones, R.J.A., Montanarella, L., Buckley, B. (eds) Land Information Systems: Developments for Planning the Sustainable Use of Land Resources, European Soil Bureau Research Report No. 4. 293-304.
2. Dent, D., Young, A., (1981): Soil Survey and Land Evaluation. George Allen & Unwin, London. 278.
3. FAO (1976): A framework for land evaluation. FAO and Agriculture Organization of the United Nations - Soil resources development and conservation service land and water development division. Food and Agriculture Organization of the United Nations. Rome.
4. Harris, R.F., Karlen, D.L., Mulla, D.J. (1996): A Conceptual Framework for Assessment and Management of Soil Quality and Health. In Methods for Assessing Soil Quality, Doran, J.W., Jones, A.J. (Edit.). SSSA Special Publication 49, Soil Science Society of America. 61-82.
5. Hartkamp, A.D., White, J.W., Hoogenboom, G. (1999): Interfacing Geographic Information Systems with Agronomic Modeling: A Review. Agronomy Journal. 91: 761-772.
6. Hearnshaw, H.M., Unwin, D.J. (1994): Visualization in geographical information systems. Wiley & Sons. 243.

7. Jurišić, M., Plaščak, I. (2009): Geoinformacijski sustavi - GIS u poljoprivredi i zaštiti okoliša. Poljoprivredni fakultet u Osijeku. 275.
8. Katalinić, I., Krnić, S., Brstilo, M., Poljak, F., Rakić, M., Buković Šošić, B., Lukšić, M., Pavlović, D., Bičak, L., Danjek, I., Jukić, I., Pejaković, D., Zagorec, D. (2009): Načela dobre poljoprivredne prakse. Ministarstvo poljoprivrede, ribarstva i ruralnog razvoja RH. Zagreb. 78.
9. Karlen, D.L., Mausbach, M.J., Doran, J.W., Cline, R.G., Harris, R.F., Schuman, G.E. (1997): Soil quality: a concept, definition and framework for evaluation. Soil Science Society of America Journal. 61: 4-10.
10. Krishna, K.R. (2013): Precision Farming: Soil Fertility and Productivity Aspects. CRC Press. 188.
11. Landon, J.R. (Ed.). (2014): Booker tropical soil manual: a handbook for soil survey and agricultural land evaluation in the tropics and subtropics. Routledge. 178-192.
12. Malvić, T. (2005): Kriging geostatistička interpolacijska metoda. 2. izdanje. Zagreb. www.mapconsult.net
13. Piorr, H.P. (2003): Environmental policy, agri-environmental indicators and landscape indicators. Agriculture, Ecosystems & Environment. 98(1): 17-33.
14. Rossiter, D.G. (1996): A theoretical framework for land evaluation (*with discussion*). Geoderma, 72: 165-202.
15. Rossiter, D.G. (2003): Biophysical Models in Land Evaluation. Encyclopedia of Life Support Systems (EOLSS), EOLSS Publishers Co. Ltd.
16. Soil Survey Division Staff (1993): Soil survey manual. Soil Conservation Service. U.S. Department of Agriculture, Handbook 18.
17. Vukadinović, V., Vukadinović, V., Kraljićak, Ž., Đurđević, B., Jug, D., Jug, I., Kokanović, M. (2012): Mogućnosti online interpretacijske baze zemljišnih resursa // Agriculture in Nature and Environment Protection / prof.dr.sc. Bojan Stipešević, Roberta Sorić, dipl. ing (ur.). Vukovar : Glas Slavonije d.d., Osijek. 306-311.
18. Vukadinović, V., Vukadinović, V. (2011): Ishrana bilja. Sveučilište Josipa Jurja Strossmayera u Osijeku. Poljoprivredni fakultet u Osijeku. 442.
19. Vukadinović, V., Vukadinović, V., Stipešević, B., Jug, I., Kraljićak, Ž. (2008): Determination of land suitability for plant production. Cereal Research Communications. 36(Part 2 Suppl S): 935-938.
20. Vukadinović, V., Bertić, B. (2013): Filozofija gnojidbe – Sve što trebate znati o gnojidbi. Autorska naklada, Osijek. 127.

Adresa autora – Authors' addresses:

izv. prof. dr. sc. Vesna Vukadinović,

e-mail: vvukadin@pfos.hr

prof. dr. sc. Vladimir Vukadinović, e-mail: vladimir@pfos.hr

izv. prof. dr. sc. Irena Jug, e-mail: ijug@pfos.hr

prof. dr. sc. Danijel Jug, e-mail: jdaniyel@pfos.hr

doc. dr. sc. Boris Đurđević, e-mail: bdurdevic@pfos.hr

Primljeno – Received:

07.04.2014.

Poljoprivredni fakultet Sveučilišta u Osijeku,
Kralja Petra Svačića 1d, 31000 Osijek

dr. sc. Željko Kraljićak, e-mail: zeljko.kraljicak@obz.hr
Osječko-baranjska županija,
Trg Ante Starčevića 2, 31000 Osijek

